

Горякин Александр,

Разработчик высоконагруженных систем хранения

данных,

Tarantool/VK



HighLoad ** Яндекс



01 Постановка задачи

- 01 Постановка задачи
- **02** Варианты интеграции БД (ETL, CT, CDC)

- 01 Постановка задачи
- **02** Варианты интеграции БД (ETL, CT, CDC)
- **ОЗ** Решения на основе CDC

- 01 Постановка задачи
- **02** Варианты интеграции БД (ETL, CT, CDC)
- **ОЗ** Решения на основе CDC
- **04** Debezium

- 01 Постановка задачи
- **02** Варианты интеграции БД (ETL, CT, CDC)
- **ОЗ** Решения на основе CDC
- **04** Debezium
- 05 Выводы

01

Постановка задачи

Необходимо переливать данные между разными источниками и потребителями – как SQL, так и NoSQL.





Необходимо переливать данные между разными источниками и потребителями – как SQL, так и NoSQL.

Требования:

• Низкий лаг репликации (40-50 мс)





Необходимо переливать данные между разными источниками и потребителями – как SQL, так и NoSQL.

Требования:

- Низкий лаг репликации (40-50 мс)
- Низкая нагрузка на БД источник





Необходимо переливать данные между разными источниками и потребителями – как SQL, так и NoSQL.

Требования:

- Низкий лаг репликации (40-50 мс)
- Низкая нагрузка на БД источник
- Устойчивость к высоким нагрузкам





Необходимо переливать данные между разными источниками и потребителями – как SQL, так и NoSQL.

Требования:

- Низкий лаг репликации (40-50 мс)
- Низкая нагрузка на БД источник
- Устойчивость к высоким нагрузкам
- Отказоустойчивость при сбоях






02

Варианты интеграции БД (ETL, CT, CDC)

Extract Transform Load Change Tracking
Change Data Capture

ETL — Extract Transform Load



Плюсы:

- Универсальный механизм
- Человекочитаемый формат данных


- Дополнительная нагрузка на источник и приемник
- Низкая скорость
- Огромный лаг
- Большой объем диска для хранения выгруженных данных







Change Tracking




Плюсы:

- Стриминг из источника
- Высокая скорость
- Низкий лаг


- Изменения в виде дельты
- Не все БД умеют из коробки
- Дополнительная нагрузка на источник и приемник
- Гарантии консистентности и тулинг свои для каждого кейса







CDC - Change Data Capture



Плюсы:

- Изменения приходят полностью
- Нет нагрузки на источник, использует WAL
- Высокая скорость
- Низкий лаг
- Гарантии консистентности данных

Минусы:

• Дополнительная нагрузка на приемник







03

Решения на основе CDC

Oracle GoldenGate + Userexit

Плюсы:

• Быстро

- Сложно
- Дорого
- Только Oracle





- Oracle GoldenGate + Userexit
- IBM Infosphere CDC GG для DB2

Плюсы:

• Быстро

- Сложно
- Дорого
- Только IBM DB2





- Oracle GoldenGate + Userexit
- IBM Infosphere CDC GG для DB2
- Самописные (например, на основе pglogrepl + pgproto)

Плюсы:

- Понимаем, как работает
- Хорошо для конкретной задачи

- Долго разрабатывать
- Неуниверсальны
- Сложно поддерживать





- Oracle GoldenGate + Userexit
- IBM Infosphere CDC GG для DB2
- Самописные (например, на основе pglogrepl + pgproto)
- Debezium





04

Debezium

Почему Debezium?
С чего мы начали
Debezium Embedded
Debezium Server

• Написан на Java





- Написан на Java
- Основные компоненты
 - Source-коннекторы (к БД источникам)







- Написан на Java
- Основные компоненты
 - Source-коннекторы (к БД источникам)
 - Debezium Embedded (библиотека, без Kafka)





- Написан на Java
- Основные компоненты
 - Source-коннекторы (к БД источникам)
 - Debezium Embedded (библиотека, без Kafka)
 - Debezium Server (готовое приложение, без Kafka)







- Написан на Java
- Основные компоненты
 - Source-коннекторы (к БД источникам)
 - Debezium Embedded (библиотека, без Kafka)
 - Debezium Server (готовое приложение, без Kafka)
 - Sink-коннекторы (к целевым БД)













Попытка с помощью Debezium заменить Oracle GoldenGate (Debezium Embedded)

• Чтение redo-логов с помощью LogMiner





Попытка с помощью Debezium заменить Oracle GoldenGate (Debezium Embedded)

- Чтение redo-логов с помощью LogMiner
- Чтение изменений с помощью XStream API





Попытка с помощью Debezium заменить Oracle GoldenGate (Debezium Embedded)

- Чтение redo-логов с помощью LogMiner
- Чтение изменений с помощью XStream API

Ho:

LogMiner нестабилен





Попытка с помощью Debezium заменить Oracle GoldenGate (Debezium Embedded)

- Чтение redo-логов с помощью LogMiner
- Чтение изменений с помощью XStream API

Ho:

- LogMiner нестабилен
- LogMiner deprecated





Попытка с помощью Debezium заменить Oracle GoldenGate (Debezium Embedded)

- Чтение redo-логов с помощью LogMiner
- Чтение изменений с помощью XStream API

Ho:

- LogMiner нестабилен
- LogMiner deprecated
- Спецификации LogMiner меняются от версии к версии





Попытка с помощью Debezium заменить Oracle GoldenGate (Debezium Embedded)

- Чтение redo-логов с помощью LogMiner
- Чтение изменений с помощью XStream API

Ho:

- LogMiner нестабилен
- LogMiner deprecated
- Спецификации LogMiner меняются от версии к версии
- XStream API по лицензии Oracle GoldenGate











Debezium Embedded

Решили

• Попробовать на примере PostgreSQL





Решили

- Попробовать на примере PostgreSQL
- Сделать более универсальным







Решили

- Попробовать на примере PostgreSQL
- Сделать более универсальным

Получили

• Монолит





Решили

- Попробовать на примере PostgreSQL
- Сделать более универсальным

Получили

- Монолит
- Высокий лаг репликации







Решили

- Попробовать на примере PostgreSQL
- Сделать более универсальным

Получили

- Монолит
- Высокий лаг репликации
- Лаг репликации растет пропорционально количеству записей





Решили

- Попробовать на примере PostgreSQL
- Сделать более универсальным

Получили

- Монолит
- Высокий лаг репликации
- Лаг репликации растет пропорционально количеству записей
- Записи приходят в JSON











Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных





Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных

Ho

• В целевой БД получаем неконсистентность данных





Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных

- В целевой БД получаем неконсистентность данных
- Перешли от JSON к Kafka SourceRecord





Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных

- В целевой БД получаем неконсистентность данных
- Перешли от JSON к Kafka SourceRecord
 - Незначительное уменьшение лага репликации (несколько минут)





Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных

- В целевой БД получаем неконсистентность данных
- Перешли от JSON к Kafka SourceRecord
 - Незначительное уменьшение лага репликации (несколько минут)
- Батчинг





Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных

- В целевой БД получаем неконсистентность данных
- Перешли от JSON к Kafka SourceRecord
 - Незначительное уменьшение лага репликации (несколько минут)
- Батчинг
 - Ещё немного уменьшили лаг (в 1.5-2 раза)






Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных

- В целевой БД получаем неконсистентность данных
- Перешли от JSON к Kafka SourceRecord
 - Незначительное уменьшение лага репликации (несколько минут)
- Батчинг
 - Ещё немного уменьшили лаг (в 1.5-2 раза)
- Батчинг + отправка в отдельном потоке







Попытались уменьшить лаг репликации

• Асинхронная прогрузка данных

- В целевой БД получаем неконсистентность данных
- Перешли от JSON к Kafka SourceRecord
 - Незначительное уменьшение лага репликации (несколько минут)
- Батчинг
 - Ещё немного уменьшили лаг (в 1.5-2 раза)
- Батчинг + отправка в отдельном потоке
 - Приемлемый лаг репликации (~40-50 мс)





Из коробки хранит оффсеты

• В файле (легко случайно удалить)





Из коробки хранит оффсеты

- В файле (легко случайно удалить)
- В Kafka (может быть недоступна)





Из коробки хранит оффсеты

- В файле (легко случайно удалить)
- В Kafka (может быть недоступна)

При падении может не восстановиться

• Храним оффсеты в БД-приёмнике





Из коробки хранит оффсеты

- В файле (легко случайно удалить)
- В Kafka (может быть недоступна)

При падении может не восстановиться

- Храним оффсеты в БД-приёмнике
- Читаем их при старте







Из коробки хранит оффсеты

- В файле (легко случайно удалить)
- В Kafka (может быть недоступна)


При падении может не восстановиться

- Храним оффсеты в БД-приёмнике
- Читаем их при старте

Ошибка записи в БД-приёмник

• Из коробки продолжит работать – плохо







Из коробки хранит оффсеты

- В файле (легко случайно удалить)
- В Kafka (может быть недоступна)

При падении может не восстановиться

- Храним оффсеты в БД-приёмнике
- Читаем их при старте

Ошибка записи в БД-приёмник

- Из коробки продолжит работать плохо
- Делаем повторные попытки записать батч





Из коробки хранит оффсеты

- В файле (легко случайно удалить)
- В Kafka (может быть недоступна)

При падении может не восстановиться

- Храним оффсеты в БД-приёмнике
- Читаем их при старте

Ошибка записи в БД-приёмник


- Из коробки продолжит работать плохо
- Делаем повторные попытки записать батч
- Начинаем отправку с ошибочной строки







Для чего хранить оффсеты?







Т.к. приложение монолитное

Плюсы:

• Все коннекторы доступны из коробки





Т.к. приложение монолитное

- Все коннекторы доступны из коробки
- Относительно гибкая конфигурация





Т.к. приложение монолитное

Плюсы:

- Все коннекторы доступны из коробки
- Относительно гибкая конфигурация

Минусы:

• Сложно масштабировать







Т.к. приложение монолитное

Плюсы:


- Все коннекторы доступны из коробки
- Относительно гибкая конфигурация

Минусы:

- Сложно масштабировать
- Любое изменение -> пересборка всего приложения












Плюсы:

• Есть готовые сборки







- Есть готовые сборки
- Легко добавить новый source-коннектор







- Есть готовые сборки
- Легко добавить новый source-коннектор
- Легко использовать с собственными source-коннекторами





- Есть готовые сборки
- Легко добавить новый source-коннектор
- Легко использовать с собственными source-коннекторами
- Просто конфигурируется





- Есть готовые сборки
- Легко добавить новый source-коннектор
- Легко использовать с собственными source-коннекторами
- Просто конфигурируется
- Легко масштабируется с помощью Kubernetes





- Есть готовые сборки
- Легко добавить новый source-коннектор
- Легко использовать с собственными source-коннекторами
- Просто конфигурируется
- Легко масштабируется с помощью Kubernetes
- Можно добавить своё хранилище оффсетов





Плюсы:

- Есть готовые сборки
- Легко добавить новый source-коннектор
- Легко использовать с собственными source-коннекторами
- Просто конфигурируется
- Легко масштабируется с помощью Kubernetes
- Можно добавить своё хранилище оффсетов

Минусы:

• Сложность добавления своего sink-коннектора (относительная)







Плюсы:

- Есть готовые сборки
- Легко добавить новый source-коннектор
- Легко использовать с собственными source-коннекторами
- Просто конфигурируется
- Легко масштабируется с помощью Kubernetes
- Можно добавить своё хранилище оффсетов

Минусы:

- Сложность добавления своего sink-коннектора (относительная)
- На каждое изменение sink'a надо пересобирать дистрибутив







Плюсы:

- Есть готовые сборки
- Легко добавить новый source-коннектор
- Легко использовать с собственными source-коннекторами
- Просто конфигурируется
- Легко масштабируется с помощью Kubernetes
- Можно добавить своё хранилище оффсетов

Минусы:

- Сложность добавления своего sink-коннектора (относительная)
- На каждое изменение sink'a надо пересобирать дистрибутив
- Из коробки хранит оффсеты в файле, в Kafka или в Redis







А что делать если источник шардирован, как, например, MongoDB или Tarantool?





А что делать если источник шардирован, как, например, MongoDB или Tarantool?

Debezium Embedded

• Масштабируем по шардам вручную





А что делать если источник шардирован, как, например, MongoDB или Tarantool?

Debezium Embedded

- Масштабируем по шардам вручную
- Оффсеты храним в приемнике для каждого шарда





А что делать если источник шардирован, как, например, MongoDB или Tarantool?

Debezium Embedded

- Масштабируем по шардам вручную
- Оффсеты храним в приемнике для каждого шарда

Debezium Server

• Масштабируем по шардам с помощью Kubernetes





А что делать если источник шардирован, как, например, MongoDB или Tarantool?

Debezium Embedded

- Масштабируем по шардам вручную
- Оффсеты храним в приемнике для каждого шарда

Debezium Server

- Масштабируем по шардам с помощью Kubernetes
- Оффсеты храним в файле, Kafka, Redis, приемнике для каждого шарда





А что делать если источник шардирован, как, например, MongoDB или Tarantool?

Debezium Embedded

- Масштабируем по шардам вручную
- Оффсеты храним в приемнике для каждого шарда

Debezium Server

- Масштабируем по шардам с помощью Kubernetes
- Оффсеты храним в файле, Kafka, Redis, приемнике для каждого шарда

Kafka-connect

• Масштабируем по шардам с помощью тасков kafka-connect







А что делать если источник шардирован, как, например, MongoDB или Tarantool?

Debezium Embedded

- Масштабируем по шардам вручную
- Оффсеты храним в приемнике для каждого шарда

Debezium Server

- Масштабируем по шардам с помощью Kubernetes
- Оффсеты храним в файле, Kafka, Redis, приемнике для каждого шарда

Kafka-connect

- Масштабируем по шардам с помощью тасков kafka-connect
- Храним оффсеты в Kafka для каждого шарда







05

• Выбрали CDC





- Выбрали CDC
- Java + Debezium





- Выбрали CDC
- Java + Debezium
- Собрали кейсы неправильного использования





- Выбрали CDC
- Java + Debezium
- Собрали кейсы неправильного использования
- Получили инструмент, реализующий необходимый функционал





- Выбрали CDC
- Java + Debezium
- Собрали кейсы неправильного использования
- Получили инструмент, реализующий необходимый функционал
- Debezium Embedded -> Debezium Server





Спасибо!

Александр Горякин

Разработчик высоконагруженных СХД,

Tarantool / VK

algoryakin@corp.mail.ru

@droidroot1995



